

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Robert Šimić

MOGUĆNOSTI PRIMJENE NEIZRAZITE LOGIKE ZA
ODREĐIVANJE REDOSLIJEDA FAZA KOD
SEMAFORIZIRANIH RASKRIŽJA

ZAVRŠNI RAD

Zagreb, 2018.

Zagreb, 29. ožujka 2018.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Automatsko upravljanje u prometu i transportu**

ZAVRŠNI ZADATAK br. 4757

Pristupnik: **Robert Šimić (0135238853)**
Studij: **Inteligentni transportni sustavi i logistika**
Smjer: **Inteligentni transportni sustavi**

Zadatak: **Mogućnosti primjene neizrazite logike za određivanje redoslijeda faza kod semaforiziranih raskrižja**

Opis zadatka:

Radi povećanja propusnosti semaforiziranih raskrižja koristi se adaptivno upravljanje signalnim planovima. Jedna od mogućnosti je mijenjanje redoslijeda faza ovisno o prometnom opterećenju. Za ispravan odabir odgovarajućeg upravljačkog algoritma potrebna je njegova simulacijska provjera. U radu je potrebno opisati problem upravljanja redoslijedom faza kod semaforiziranih raskrižja, napraviti odgovarajuće simulacijsko okruženje korištenjem PTV VISSIM-a i MATLAB-a te napraviti simulaciju jednostavnog algoritma za upravljanje redoslijedom faza primjenom neizrazite logike.

Mentor:



izv. prof. dr. sc. Edouard Ivanjko

Predsjednik povjerenstva za
završni ispit:

SVEUČIŠTE U ZAGREBU FAKULTET PROMETNIH ZNANOSTI

ZAVRŠNI RAD

MOGUĆNOSTI PRIMJENE NEIZRAZITE LOGIKE ZA ODREĐIVANJE REDOSLIJEDA FAZA KOD SEMAFORIZIRANIH RASKRIŽJA

POSSIBILITY OF APPLYING FUZZY LOGIC IN DETERMINING PHASE ORDER FOR SIGNALIZED INTERSECTIONS

Mentor: izv. prof. dr. sc. Edouard Ivanjko

Student: Robert Šimić

JMBAG: 0135238853

Zagreb, rujan 2018.

SAŽETAK

MOGUĆNOSTI PRIMJENE NEIZRAZITE LOGIKE ZA ODREĐIVANJE REDOSLIJEDA FAZA KOD SEMAFORIZIRANIH RASKRIŽJA

U ovom završnom radu opisan je sustav adaptivnog upravljanja signalnih planova semaforiziranog raskrižja koji koristi neizrazitu logiku u svrhu boljeg iskorištavanja kapaciteta prometnice, smanjivanja redova i vremena čekanja, upravljanje ulaznim i izlaznim tokovima te prevenciju prometnog zagušenja. S obzirom na sve veće korištenje cestovnih vozila u prometu, potrebno je optimizirati prometne tokove unutar već postojeće infrastrukture korištenjem tehnologija u sklopu inteligentnih transportnih sustava. Izrađeni sustav koristi se isključivo promjenom redoslijeda signalnih faza kako bi se optimizirali slučajevi prometne potražnje na izoliranom semaforiziranom raskrižju. Korištenje neizrazite logike omogućuje pokrivanje mogućih slučajeva popunjenosti prometnih tokova korištenjem unaprijed definiranih pravila na temelju kojih se vrši izmjena signalnih faza.

KLJUČNE RIJEČI: adaptivno upravljanje, neizrazita logika, promjena faza, semaforizirano raskrižje, prometno zagušenje, inteligentni transportni sustavi, mikroskopska simulacija

SUMMARY

POSSIBILITY OF APPLYING FUZZY LOGIC IN DETERMINING PHASE ORDER FOR SIGNALIZED INTERSECTIONS

In this bachelor's thesis an adaptive control system for signalized intersections has been presented. The system uses fuzzy logic to fully optimize traffic flow, minimize wait times, queue length and controlling arrival and exit flow in order to prevent traffic congestion throughout the observed signalized intersection. Given that road traffic's use has been largely increased over years, it is necessary to optimize traffic flow in an already existing traffic infrastructure using technologies within intelligent transport systems. The designed system makes an exclusive use of changing the signal phase order to optimize functionality for all traffic demand scenarios covered in this work. Fuzzy logic enables the use of predefined rules which serve as a base for predicting possible cases of traffic flow, thus giving a better insight over further optimizing phase order in the intersection.

KEYWORDS: adaptive control, fuzzy logic, phase order, signalized intersection, traffic congestion, intelligent transport systems, microscopic simulation

SADRŽAJ

SAŽETAK.....	4
SUMMARY	5
1. UVOD	1
2. UPRAVLJANJE REDOSLIJEDOM FAZA U SIGNALNIM PLANOVIMA SEMAFORIZIRANIH RASKRIŽJA	2
2.1. FIKSNO UPRAVLJANJE SEMAFORIZIRANIM RASKRIŽJEM	3
2.2. ADAPTIVNO UPRAVLJANJE SEMAFORIZIRANIM RASKRIŽJEM	4
2.3. STRUKTURA NEMA	5
3. NEIZRAZITA LOGIKA I NJENA PRIMJENA U UPRAVLJANJU SIGNALNIM PLANOVIMA	9
3.1. NEIZRAZITA LOGIKA	9
4. NEIZRAZITI SUSTAV ZA ODREĐIVANJE REDOSLIJEDA FAZA	13
4.1. PRIKUPLJANJE PODATAKA.....	14
4.2. OBRADA PODATAKA	15
5. SIMULACIJSKO OKRUŽENJE	17
5.1. MATLAB PROGRAMSKO OKRUŽENJE	17
5.2. NEIZRAZITA LOGIKA U MATLAB OKRUŽENJU.....	19
5.3. SIMULACIJSKI PAKET PTV VISSIM	23
5.4. POVEZIVANJE APLIKACIJA COM SUČELJEM	24
6. REZULTATI SIMULACIJA	26
6.1. REZULTATI SCENARIJA SREDNJE PROMETNE POTRAŽNJE.....	29
6.2. REZULTATI SCENARIJA UMANJENE PROMETNE POTRAŽNJE.....	34
6.3. REZULTATI SCENARIJA UVEĆANE PROMETNE POTRAŽNJE.....	38
7. ZAKLJUČAK.....	43
LITERATURA	44
POPIS SLIKA.....	45
POPIS TABLICA	47
ZAHVALE	48


1. UVOD

Potreba za adaptivnim načinom upravljanja cestovnim prometom javlja se s povećanjem prometne potražnje. Adaptivni sustavi upravljanja omogućeni su dolaskom novih tehnologija. Veća potražnja usluga na već postojećoj prometnoj infrastrukturi izazvala je pojavu periodičnih zagušenja pa tako dosadašnji načini upravljanja više nisu dostatni, posebice u gusto naseljenim sredinama. Samim porastom prometne potražnje, semaforizirana raskrižja pokazala su se kao dovoljno dobro rješenje u upravljanju prometnom mrežom. Daljnjim porastom broja cestovnih vozila te sve složenijom prometnom infrastrukturom, porasla je i potreba za modernizacijom prometnog sustava te su nova rješenja iz područja inteligentnih transportnih sustava (ITS) dovela i do novih načina adaptivnog upravljanja. U ovome je završnom radu opisana potreba za adaptivnim upravljanjem uslijed problema koji nastaju kao posljedica zagušenja na semaforiziranim raskrižjima. S obzirom na stohastičku prirodu prometnih tokova, korištena je neizrazita logika kako bi se izradio sustav upravljanja simuliranim izoliranim semaforiziranim raskrižjem. Također se razmatra stvarnovremensko ponašanje izoliranog semaforiziranog raskrižja te na temelju rezultata prikazanih u obliku međuodnosa odabranih ulaznih i izlaznih prometnih parametara. Na kraju je predstavljen općenit zaključak o korištenju neizrazitih sustava upravljanja na semaforiziranim raskrižjima.

Ovaj završni rad je organiziran kako slijedi. Nakon uvodnog dijela, u drugom su poglavlju opisani osnovni pojmovi korišteni u svrhu prometnog upravljanja semaforiziranim raskrižjima, razlika između fiksnog i adaptivnog upravljanja te struktura NEMA kao tehnika za izradu signalnih planova pogodnih za adaptivno upravljanje korišteno u ovom radu. Treće poglavlje opisuje neizrazitu logiku i njezinu primjenu, dok se u četvrtom poglavlju govori o primjeni neizrazite logike unutar adaptivnog sustava upravljanja semaforiziranim raskrižjem. Peto poglavlje pokriva programsko i simulacijsko okruženje korišteno za implementaciju te simulacijsku provjeru rada upravljačkog sustava, dok šesto poglavlje predstavlja rezultate simulacija i potkrepljuje ih objašnjenjem s obzirom na sam način na koji je sustav adaptivnog upravljanja sastavljen. Rad završava zaključkom i komentarima za budući rad na ovoj temi.

2. UPRAVLJANJE REDOSLIJEDOM FAZA U SIGNALNIM PLANOVIMA SEMAFORIZIRANIH RASKRIŽJA

Upravljanje kao pojam poprilično je širok te je potrebno razaznati načine na koje se ono može postići u kontekstu semaforiziranog raskrižja. Najprije, potrebno je spomenuti način na koji semafor kao osnovni element upravljanja semaforiziranim raskrižjem vrši svoju funkciju. Kako bi obavljao svoju zadaću, semafor je pogonjen upravljačkim uređajem koji sadrži unaprijed definirane signalne planove za raskrižje na kojem se nalazi. Signalni plan zabilježen je u obliku matrice koja pokazuje sve kombinacije faza koje se mogu istovremeno izvoditi uz uvjet da nisu konfliktne, zajedno s duljinama svake pojedine faze, zaštitnog međuvremena itd. Pojam faze najlakše se može opisati kao vremenski interval unutar kojeg pojedini prometni tokovi imaju slobodan prolaz raskrižjem. Pojam konfliktnih faza označava nemogućnost njihovog istovremenog uključivanja zelenog i žutog svjetla unutar signalnog plana bez rizika za sigurnost sudionika u prometu. Slobodan prolaz prometa okarakteriziran je zelenim, dok je zabrana prolaza prikazana crvenim svjetlosnim signalom. Kada se generalno opisuje promjena redoslijeda faza, najčešće je u pitanju fiksna izmjena već unaprijed definiranih faza po jednakom redoslijedu u svakom sljedećem ciklusu, odnosno vremenu koje je potrebno da sve faze koje su uključene u prometni plan završe svoje djelovanje, čime se proces ponavlja svaki put (Slika 1). Duljina pojedine faze određena je kapacitetom prometnice, odnosno pripadnosti određenih traka glavnim ili sporednim prometnim trakama te može biti sačinjena od više signalnih grupa. Određivanje optimalnog broja faza, njihove duljine i redoslijeda sprječava nastajanje križanja konfliktnih prometnih tokova, a time i potencijalnih incidentnih situacija.



Slika 1. Općeniti primjer korištenja faza u fiksnom signalnom planu [2]

U nastavku u tablici 1, prikazuje optimalnu duljinu ciklusa s obzirom na broj faza postavljenih na semaforizirano raskrižje [3].

Tablica 1. Duljina ciklusa s obzirom na broj faza


Broj faza	Duljina ciklusa [s]	Opis
2	(30) 40-70	Minimalne vrijednosti su za pješačke prijelaze
3	70-90 (100)	Maksimalne vrijednosti se rijetko koriste (maksimalno do 30-60 minuta u vršnom satu)
4	90-120	Najčešće iznad 100
5	≥ 110	5. faza najčešće je zvana „uvjetna“ te se ostvaruje skraćivanjem drugih faza

Za mogućnost ostvarivanja promjene faza potrebno je imati više od dvije faze u signalnom planu. U ovom završnom radu korišteno je semaforizirano raskrižje s 4 ili više faza pa su samo zadnja dva retka tablice 1 primjenjivi.

2.1. FIKSNO UPRAVLJANJE SEMAFORIZIRANIM RASKRIŽJEM

Sve većim i bržim širenjem prometne mreže te povećanjem broja vozila pojavila se i potreba za modernizacijom pristupa rješavanju problema koji se s takvim naglim rastom pojavljuju. Tako je donedavno fiksno upravljanje bilo sasvim dostatno za potrebe prometne mreže, uzimajući u obzir manja semaforizirana raskrižja. Ovakav način upravljanja semaforiziranim raskrižjima najčešće je korišten, ali je isto tako i najneučinkovitiji u smislu optimizacije prometnih tokova vezano za promjenjivu prometnu potražnju, ponajviše u slučajevima kada se radi o složenijim raskrižjima. Pod pojmom „fiksno“, smatra se da su sve veličine vezane uz djelovanje sustava upravljanja semaforiziranim raskrižjem nepromjenjive za vrijeme rada sustava. To se na primjer odnosi na duljinu, redoslijed i broj faza te posljedično tome i duljinu trajanja ciklusa. S obzirom na to da fiksni sustavi upravljanja ne dozvoljavaju nikakvu dinamičku izmjenu tokom samog rada kao što je to sastav faza, potrebno je pažljivo odabrati koji prometni tokovi najbolje međusobno odgovaraju jedni drugima uz uvjet da se predviđena prometna potražnja optimizira na najbolji mogući način. Na slici 2 prikazan je fiksni

signalni plan kakav je korišten u ovom radu tijekom simulacija za dobivanje rezultata kod razmatranih scenarija različite prometne potražnje za slučaj fiksnog signalnog plana.



Slika 2. Fiksni signalni plan korištenog semaforiziranog raskrižja Zagrebačke ulice i Zagrebačke avenije

2.2 ADAPTIVNO UPRAVLJANJE SEMAFORIZIRANIM RASKRIŽJEM

Adaptivno upravljanje semaforiziranim raskrižjem (engl. ATCS – Adaptive Traffic Control Systems) je sustav upravljanja koji vrši prilagodbu signalnih planova na osnovi trenutne prometne situacije, prometnih zahtjeva i kapaciteta prometne mreže korištenjem algoritama koji prilagođavaju [4]:

- omjer trajanja zelenog signalnog pojma prema ciklusu;
- vremenski pomak signalnog plana;
- trajanje faza;
- redoslijed faza.

S obzirom na prometna zagušenja koja se događaju na semaforiziranim raskrižjima, moguće je koristiti tehnike dodjele prioriteta za pojedini privoz ili vozila javnog gradskog prijevoza [4]:

- produljenje faze zelenog svjetla;
- skraćivanje faze zelenog svjetla;
- dodatna faza;
- ispuštanje faze.

Nedostatak koji imaju adaptivni sustavi jest potreba za ulaganjem sredstava u modernizaciju infrastrukture kako bi implementirani adaptivni sustavi radili nesmetano te se omogućilo njihovo održavanje kroz vrijeme. Ipak, kada se govori o dugogodišnjem ulaganju, adaptivni sustavi znatno smanjuju troškove. Prednosti adaptivnih sustava su [4]:

- a) upravljanje konfliktima između cestovnog i ostalih vidova prometa;
- b) smanjenje ukupnih troškova prometnog sustava;
- c) upravljanje prometom u posebnim situacijama;
- d) smanjenje troškova reprogramiranja signalnih planova svakih 3 – 5 godina zbog konstantnog rasta prometne potražnje;
- e) potreba za upravljačkim sustavima koji mogu zadovoljiti potrebu upravljanja pri velikim promjenama prometne potražnje.


Implementacija adaptivnog upravljanja kao ITS rješenja omogućuje uporabu stvarnovremenskih podataka dobivenih s detektora postavljenih na površinu prometnice. Ti se podaci potom obrađuju u svrhu poboljšanja stanja na određenoj dionici po potrebi, što između ostalog uključuje i promjenu redoslijeda faza kako je i opisano. U ovom završnom radu, velika je pozornost usmjerena na samu vrstu prometnih tokova s obzirom na prometnu potražnju te s obzirom na kriterij prometne potražnje, postoji podjela na glavne i sporedne prometne tokove, gdje glavni privozi označavaju prometnice za tokove veće, a sporedni privozi prometnice za tokove manje potražnje. Korištenje adaptivnih sustava upravljanja rješava ovaj problem na način da se uporabom pristupa poput neizrazite logike omogućuje dinamična izmjena faza unutar ciklusa po potrebi s obzirom na prometnu potražnju. Kada se govori o adaptivnom upravljanju semaforiziranim raskrižjem, ono se može odnositi na dinamični poredak faza, njihovo uključivanje i isključivanje tokom rada sustava, produljenje i skraćivanje faza po potrebi, a time i samog ciklusa itd. Unutar ovog završnog rada adaptivno upravljanje odnosi se na promjenu faza na temelju trenutnog stanja unutar same simulacije te kasnije korištenje podataka koji su prikupljeni kroz dulje vrijeme u cilju dugoročnije optimizacije sustava [3].

2.3. STRUKTURA NEMA

S obzirom na već spomenutu podjelu načina upravljanja signalnim planovima semaforiziranih raskrižja na fiksne i adaptivne, potrebno je opisati konkretniji način na koji adaptivno upravljanje vrši svoju funkciju u usporedbi s fiksnim. Signalni uređaji koji koriste

fiksni signalni plan jednostavniji su u svojoj izvedbi te kao takvi zahtijevaju manje troškove održavanja. Korištenje adaptivnog upravljanja u signalnim uređajima podrazumijeva uporabu algoritma koji u realnom vremenu vrši promjenu signalnog plana. Iako sustavi s fiksnim djelovanjem omogućuju lakšu implementaciju, dugoročnom primjenom adaptivnog upravljanja smanjuje se vrijeme čekanja na raskrižjima, smanjuju redovi čekanja te povećava protok vozila na već postojećoj infrastrukturi. To omogućuje standard NEMA (engl. National Electronic Manufacturer Association) u obliku NEMA kompatibilnih regulatora (upravljačkog uređaja) koji u svojoj širokoj primjeni omogućuju i oblik adaptivnog upravljanja korištenog u signalnim uređajima.


Uz korištenje NEMA upravljačkog uređaja te potrebne programske podrške, omogućuje se izvođenje adaptivnog upravljanja u obliku prstenaste strukture faza (Slika 3). Struktura se u odnosu na fiksni signalni plan sastoji od potpuno drukčije skupine faza koje su sastavljene od njima pripadajućih prometnih traka.



Slika 3. Prikaz osnovne građe prstenaste strukture NEMA

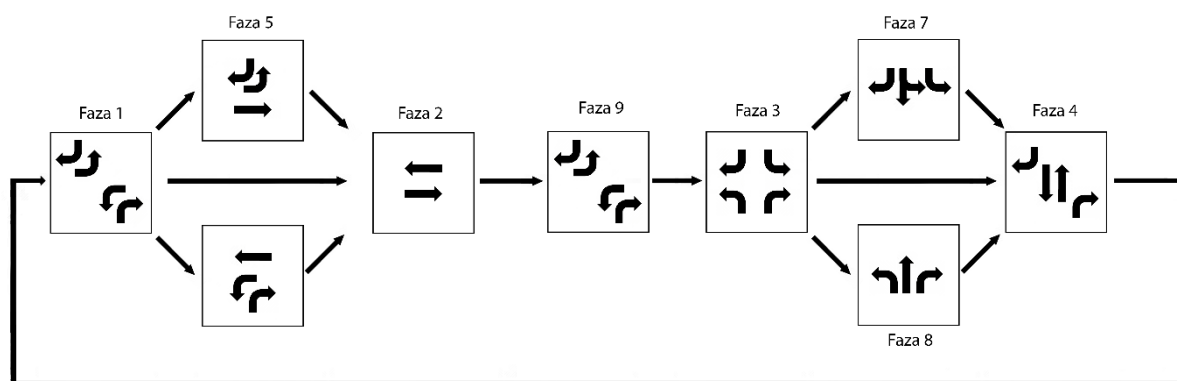
U ovom završnom radu inicijalno je korištena prstenasta struktura NEMA koja je dizajnirana tako da sadrži 4 faze koje se obavezno izvršavaju pri svakom ciklusu te 4 faze koje su iskoristive u slučaju visoke hitnosti pojedinih traka koje zahtijevaju dodatno otpuštanje opterećenja. S obzirom na raspored faza u fiksnom signalnom planu definira se struktura NEMA po vlastitoj procjeni, uzimajući pritom u obzir odnos glavnih i sporednih privoza te međusobno kompatibilnih prometnih traka koje spadaju u te dvije kategorije. Novonastali

signalni plan sastoji se od dvije skupine faza koje je moguće izvoditi u svakom ciklusu po redu u kojem su raspoređene. Struktura NEMA podrazumijeva kombinaciju faza koje se obavezno izvode svaki ciklus bez iznimke te onih koje su neobavezne u svom izvođenju te potpuno ovise o razini opterećenja privoza od kojih se sastoje te zahvaćenosti pravilima neizrazite logike unutar algoritma za adaptaciju signalnog plana u upravljačkom uređaju. U opisanoj strukturi, faze 1-4 obavezne su, dok su one označene 5-8 opcionalne (Slika 4). U koraku provjere sljedeće faze potkraj izvođenja jedne od obaveznih faza, upravljački sustav ima izbor između dvije trenutno ponuđene neobavezne faze te odabire onu s većom hitnošću. Također postoji i mogućnost izvedbe samo obaveznih faza uz potpuno zanemarivanje opcionalnih u slučaju da se trenutna prometna potražnja poklapa s distribucijom traka po definiranim obaveznim fazama. Kako bi se onemogućilo djelovanje konkurentnih faza u isto vrijeme, obično se koristi matrica konkurentnosti.



Slika 4. Prikaz korištene prstenaste strukture NEMA

Način određivanja duljine pojedinih faza unutar prstenaste strukture također je bitan aspekt konstruiranja adaptivnog sustava ovakve vrste. Posebno jer se radi o proizvoljno grupiranim prometnim trakama koje sačinjavaju faze. Pri određivanju trajanja svake pojedine faze, važno je promatrati pripadaju li trake glavnim ili sporednim privozima te prema tome rasporediti trajanje među fazama. U ovom slučaju, trajanje ciklusa unutar prstenaste strukture iznosi 150 sekundi, što je promjenjivo samo ovisno o tome izvršavaju li se pojedine opcionalne faze ili ne.



Slika 5. Prikaz alternativne strukture NEMA

Slika 5 Prikazuje alternativnu strukturu NEMA korištenu u svrhu poboljšanja dobivenih rezultata na temelju slike 6. Razlika između dvije korištene strukture očituje se u dodanoj 9. fazi druge strukture, kao i u vremenu trajanja ciklusa, budući da ciklus alternativne strukture NEMA traje 180 sekundi.


3. NEIZRAZITA LOGIKA I NJENA PRIMJENA U UPRAVLJANJU SIGNALNIM PLANOVIMA

Potreba korištenja neizrazite logike u komercijalne svrhe javila se prvi put 1985. godine u japanskom gradu Sendai s ciljem dizajniranja poboljšanog sustava upravljanja kočenja vlakova za japanski željeznički sustav. Takav uspjeh modernizacije prometne infrastrukture dao je podlogu za daljnje istraživanje mogućih načina uporabe neizrazitih sustava, kako unutar prometne struke, tako i primjenom u sustavima korištenih na dnevnoj razini. Primjer primjene sustava neizrazite logike može se naći u upravljačkim računalima ugrađenih u perilicama za rublje koja prikupljaju informaciju o količini rublja i razini nečistoće vode, na temelju čega se vrši optimizacija potrošnje električne energije, vode i deterdženta. Uporaba neizrazite logike u širokoj je uporabi u polju robotike te bilo kojoj grani tehnologije koja zahtjeva neku vrstu međusobne ovisnosti više ulaza koja se neposredno odražava na izlaznu vrijednost sustava. Neizrazita logika također omogućuje smanjenje cijene izrade komponenti i korištenja mikro računala za upravljanje.

U sklopu ovog završnog rada korišten je sustav neizrazite logike kako bi se mogli obraditi simulacijski rezultati u stvarnom vremenu te iskoristiti za daljnje upravljanje. Odabir neizrazite logike u svrhu adaptivnog upravljanja nastao je zbog mogućnosti korištenja prometnih podataka za vrijeme simulacije kao reference za daljnje djelovanje samog sustava neposredno nakon očitavanja trenutne aktivne faze. Temeljno tome, sljedeća se faza prilagođava prometnim podacima izmjeranim u prijašnjoj fazi korištenjem prometne potražnje na pripadnoj prometnoj traci. Na taj je način uključivanjem odabira opcionalnih ili samo obveznih faza prema strukturi NEMA, duljina samog ciklusa također promjenjiva.

3.1. NEIZRAZITA LOGIKA

Prije samog opisa adaptivnog sustava koji je korišten, potrebno je ukratko opisati način na koji neizrazita logika obavlja svoju zadaću unutar sustava upravljanja. Za početak, neizrazitu logiku potrebno je promatrati kao proširenje Booleove logike, koja označava kretanje vrijednosti ulaznih i izlaznih varijabli na intervalu između izrazitih vrijednosti „0“ i „1“. Slike 5, 6 i tablice 2, 3 prikazuju brojčane i grafičke odnose vrijednosti Booleovih i neizrazitih vrijednosti.



Slika 5. Prikaz funkcije pripadnosti izrazitom skupu, [5]


Tablica 2. Vrijednosti funkcija izrazitih skupova, [5]

Broj vozila	Mala	Srednja	Velika
7 vozila	1	0	0
12 vozila	0	1	0
23 vozila	0	0	1

Na slici 6., y-os prikazuje funkciju pripadnosti „ $\mu(x)$ “, koja označava mjeru u kojoj vrijednost na y-osi poprima istinitost za predefinirani pojam postavljen u pravilima neizrazite logike. Vrijednosti varijabli ulaza i izlaza neizrazitih sustava opisuju pripadnost pojedinom unaprijed definiranom neizrazitom (simboličkom) pojmu koji je već postavljen pri dizajniranju sustava, na primjer: ulazna varijabla broja vozila (Slika 6) toka prometnice jednak je „x vrijednost“ te se pridružuje pojmu „srednja“ (Tablica 3). Karakteristika neizrazite logike da u isto vrijeme omogućuje istovremenu uporabu brojčanih i jezičnih prikaza podataka te daje mogućnost izrade složenijih sustava upravljanja bez nužnog oslanjanja na složene matematičke izraze tijekom cijelog procesa. Ta se specifičnost posebno ističe pri izradi složenijih sustava s velikim brojem pravila te daje priliku za njihovu izmjenu uz minimalne posljedice po djelovanje sustava bez obzira na fazu razvoja u kojoj se sustav u tom trenutku nalazi.

Kompozicija sustava koji koriste neizrazitu logiku sastoji se od:

- Jasno definiranih ulaznih i izlaznih varijabli;
- Pravila neizrazite logike koja opisuju međuodnose svih ulaza i izlaza sustava;
- Funkcija pripadnosti koje opisuju pridruživanje izrazite vrijednosti neizrazitoj za svaku pojedinu simboličku vrijednost.




Slika 6. Prikaz funkcije pripadnosti neizrazitom skupu, [5]

Tablica 3. Vrijednosti funkcija neizrazitih skupova, [5]

Broj vozila	Mala	Srednja	Velika
7 vozila	0,8	0,3	0
12 vozila	0,2	0,8	0
23 vozila	0	0,3	0,9

Međukoraci koje neizrazita logika koristi nazivaju se fuzifikacija i defuzifikacija. Proces fuzifikacije specifičan je za sustave neizrazite logike upravo zbog toga što pretvara izrazite vrijednosti u neizrazite. Obratno tome, defuzifikacija vraća simboličke vrijednosti natrag u numeričke vrijednosti potrebne za evaluaciju neizrazitih pravila [6].



Slika 7. Proces odlučivanja primjenom neizrazite logike

Pravila neizrazite logike glavni su sastavni dio sustava upravljanja te kao takvi najbolji su pokazatelj načina na koji je sustav dizajniran. Promatrajući pravila neizrazite logike, moguće je jasno ustvrditi međusobni odnos između ulaznih veličina te način na koji će se njihovo međusobno djelovanje u danom trenutku odraziti na izlazne veličine sustava. Upravo zbog takve velike varijabilnosti, svaki je sustav specifičan s obzirom na svrhu za koju je konstruiran. Potrebno je napomenuti da s obzirom na broj ulaznih varijabli, broj pravila brzo raste zbog čega je razmatranje idealnog načina same konstrukcije pravila sustava upravljanja iznimno važno. U svrhu ovog završnog rada, neizraziti sustav upravljanja koristi četiri ulazne i jednu izlaznu veličinu te kao posljedicu toga – 81 pravilo. Pregled pravila za vrijeme dizajniranja neizrazitog sustava upravljanja omogućuje stalan uvid u sve korištene varijable i posljedice koje se događaju promjenom njihovog međusobnog odnosa.

Korištenje neizrazite logike moguće je zamijeniti još nekim alternativama, iako niti jedna nije dostatna u svakom aspektu. Jedna od mogućnosti je korištenje tablica vrijednosti koje pokrivaju svaku moguću kombinaciju vrijednosti ulaznih i izlaznih varijabli. Takvo rješenje naočigled daje zadovoljavajuće rješenje, no ostavlja dosta prostora za pogreške s obzirom na to da upravljačko računalo treba neprestano „skakati“ s jednog na drugo mjesto u tablici. Složenost broja podataka je također problem pri sastavljanju takve tablice rješenja, budući da ne mogu sva računala podnijeti rad s tolikom količinom memorije. Druga mogućnost dolazi u obliku matematičkih formula koje opisuju sustav na način da izražavaju izlaz kao funkciju više kombiniranih ulaza. Problem s takvim sustavom jest što složene matematičke formule brzo mogu postati vrlo zahtjevne za procesor računala te znatno usporiti rad samog izračuna rješenja, posebno kada se radi o složenijim sustavima.

Neizrazita logika zaobilazi svu spomenutu problematiku s obzirom na to da daje mogućnost dizajniranja sustava na temelju znanja i iskustva operatera (u ovom slučaju prometnog stručnjaka) te zanemaruje potrebu za ikakvim oblikom složenijeg matematičkog modeliranja. Na taj način se eliminira složenost koju posjeduju alternativna rješenja i ne sprječava mogućnost prikupljanja i obrade stvarnovremenskih simulacijskih podataka.

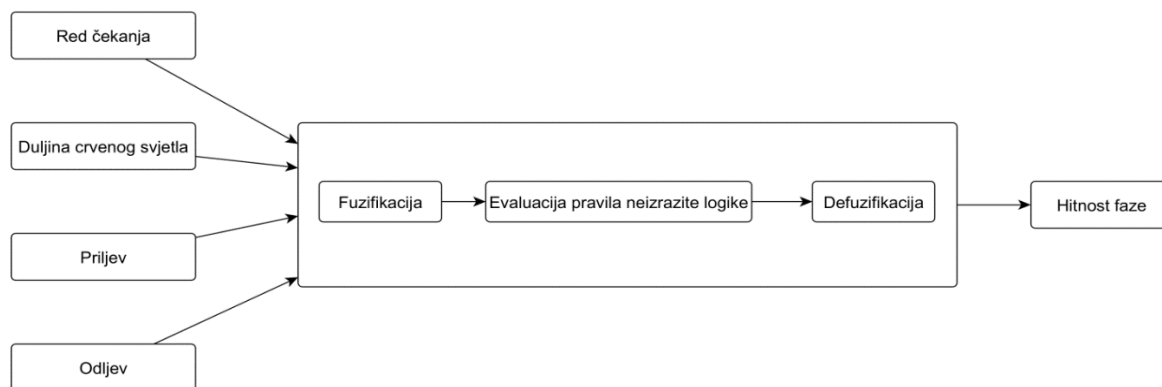
4. NEIZRAZITI SUSTAV ZA ODREĐIVANJE REDOSLIJEDA FAZA

Cilj korištenja neizrazitog sustava upravljanja semaforiziranim raskrižjem jest dakako smanjivanje zagušenja te optimizacija protoka vozila s obzirom na kapacitet prometnice u stvarnom vremenu. Već spomenuta podjela privoza na glavne i sporedne najbitnija je odrednica dizajna ovakvog sustava za adaptivno upravljanje te se s obzirom na to koriste dva različita sustava upravljanja unutar upravljačkog uređaja zasnovanog na neizrazitoj logici. Svaki od dva spomenuta sustava upravljanja neizrazite logike posjeduje jednake ulazne veličine koje su mjerene prilikom svake faze te se koriste u svrhu određivanja izlaza sustava, odnosno hitnosti. Hitnost u ovom kontekstu određuje koja od postojećih faza ima najveće predispozicije za stvaranje zagušenja (ili ako ono već postoji) nakon čega se na temelju tog izračuna u sljedećem ciklusu kreira novi slijed faza pogodan očitanoj situaciji [6]. Ulazi koji su pri kreiranju ovog simulacijskog modela uzeti obzir bili su red čekanja, duljina crvenog svjetla te priljev i odljev vozila s raskrižja, dok je izlaz koji odražava korelaciju tih ulaza – hitnost promjene faze. Kako bi se postigla standardizacija veličina te se isti ujednačili tijekom rada sustava upravljanja, sve ulazne varijable pa tako i izlaz poprimaju vrijednosti između „0“ i „1“. U nastavku je svaki od navedenih ulaza pobliže opisan u cilju boljeg razumijevanja samog djelovanja ovog sustava.

Svaki od ovih ulaza korištenih od strane neizrazitog sustava upravljanja, posredni je ili neposredni pokazatelj zagušenja na promatranom raskrižju. Prilikom samog planiranja izrade sustava, red čekanja se pokazao kao izrazito važna veličina, budući da je najbolji pokazatelj trenutnog zagušenja na promatranom raskrižju te je upravo iz tog razloga iskorišten kao vodeća veličina u odlučivanju hitnosti pojedine faze unutar trenutnog ciklusa. Duljina trajanja crvenog svjetla na semaforima prometnih traka također je uzeta u obzir te pridonosi stvaranju zagušenja u slučaju ako su ulazi reda čekanja i duljine crvenog svjetla proporcionalnih veličina. Varijable priljeva i odljeva vozila iako su ovdje obrnuto proporcionalne veličine koje opisuju ulazak i izlazak vozila iz mreže, trebaju biti promatrane kao dolazak iz prošlog i ulazak u sljedeće raskrižje u mreži, što za razliku od ovog simuliranog raskrižja u kooperativnom upravljanju čini veliku razliku.

Uzimajući sve ulaze u obzir, izlaz hitnosti pokazuje trenutni utjecaj ulaza na upravljački sustav. Programski dio unutar kojeg je konstruirana funkcija hitnosti djeluje na način da su prilikom trenutne faze uzete u obzir i preispitane hitnosti svih prometnih traka smještenih u pripadne faze. Prilikom evaluacije, vrijednosti hitnosti svih pojedinih traka zbrajaju se te zatim dijele s brojem traka unutar pripadne faze, čime je izračunat broj koji opisuje hitnost pojedine

faze. Slijedno tome, hitnosti trenutno aktualnih faza se uspoređuju i poredaju po veličini, dajući time uvid programskom dijelu koju fazu sljedeću izabrati. Na slici 8 najbolje je prikazan odnos ulaza naprema izlazu ovog sustava te međukoraci fuzifikacije i izvršavanja pravila neizrazite logike.



Slika 8. Prikaz cjelokupnog djelovanja neizrazitog sustava za izmjenu faza

4.1. PRIKUPLJANJE PODATAKA

Prikupljanje podataka u svrhu korištenja ulaznih varijabli neizrazitog upravljača vrši se pomoću 35 detektora na 15 prometnih traka unutar simuliranog modela semaforiziranog raskrižja. Unutar mikroskopskog simulacijskog modela, detektori su postavljeni na sve prometne trake te bilježe prisutnost i duljinu vozila. U svrhu zabilježbe vozila korišteni su detektori razvrstani u tri različite kategorije s obzirom na njihov položaj unutar pojedine trake te jasno opisuju pripadnost pojedinoj varijabli neizrazitog sustava upravljanja (slika 9).



Slika 9. Prikaz označavanja detektora unutar modela semaforiziranog raskrižja

Detektori se za ovu primjenu dijele na:

- Detektori priljeva vozila;
- Detektori odljeva vozila;
- Detektori reda čekanja.

Međusobna udaljenost detektora od samog raskrižja uvjetovana je duljinom prometne trake na kojoj se oni nalaze. To je pravilo koje se odnosi na detektore predviđene za mjerenje reda čekanja i priljeva vozila, a generalno se uzima da ukoliko je duljina mjerene prometnice ≥ 400 metara, detektori budu postavljeni na udaljenost od 150 metara od samog semaforiziranog raskrižja. Suprotno tome, ako je duljina prometne trake koja se mjeri manja od 400 metara, primjenjuje se sljedeća formula preuzeta iz [7]: $150 \times \frac{\text{duljina trake}}{400}$. Osim detektora koji su postavljeni na svaku prometnu traku, postavljeni su i brojači reda čekanja (engl. Queue Counters) koji očitavaju red čekanja vozila koja već miruju na samom raskrižju. Brojači reda čekanja su ovisni o priljevnim tokovima te ih ima 5 sveukupno. Osim prikupljanja podataka o duljini reda čekanja, priljevu i odljevu vozila na temelju duljine zabilježenih vozila i položaju detektora, tijekom simulacije se također prikupljaju podaci o duljini crvenog svjetla koji ulaze u izračun hitnosti promjene faze. Također se bilježi i redoslijed faza nastalih korištenjem strukture NEMA te je moguće vidjeti koje su faze izabrane najčešće, označavajući time visoku hitnost koju pripadne trake posjeduju.

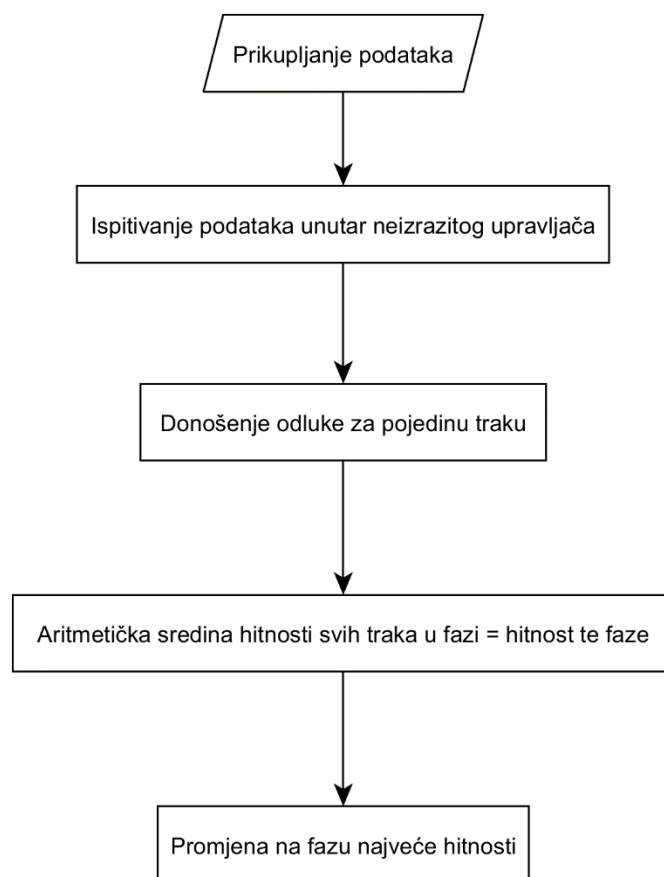
4.2. OBRADA PODATAKA

Nakon što su podaci izmjereni, spremaju u matricu podataka gdje se pohranjuju sve simulacijske informacije. Budući da se podaci obrađuju u stvarnom vremenu prije same pohrane, potrebno je u obzir uzeti način na koji se evaluiraju određene vrijednosti koje povezuju neizrazitu logiku s odabranim semaforiziranim raskrižjem. Računanje hitnosti faze, a posljedično tome i izmjena faza, postiže se prolaskom svakom od traka na kojima su simulirani signalni uređaji. Uzimajući u obzir trake koje se u pojedinoj fazi nalaze, računa se hitnost pojedine faze te se rezultat sprema u već spomenutu matricu. Formula koja opisuje proces računanja hitnosti faze glasi (1):

$$H_{\text{faze } j} = \frac{\sum_{i=1}^n \text{hitnost trake } i}{n}, \quad (1)$$

gdje je:

- 1) $H_{faze\ j}$ – hitnost trenutno izračunate faze;
- 2) hitnost trake i – hitnost pojedine trake koja se računa;
- 3) n – broj traka unutar faze koja se računa;
- 4) i – indeks prometne trake;
- 5) j – indeks faze koja se trenutno računa.



Slika 10. Prikaz određivanja hitnosti faza

5. SIMULACIJSKO OKRUŽENJE

Kako bi cjelokupni sustav funkcionirao na simulacijskoj i logičkoj razini, prilikom izrade ovog rada u upotrebi su bili mikroskopski programski paket PTV Vissim 10 i programsko okruženje MATLAB 2016b. MATLAB je korišten za dizajn cijelog sustava adaptivnog upravljanja te manipuliranje svakim aspektom neizrazite logike kao i za pokretanje simulacije prometa. Simulacijski paket PTV Vissim korišten je sveukupno prometno modeliranje raskrižja Zagrebačke ulice i Zagrebačke avenije te korištenje podataka o prometnoj potražnji kao i ostalih prometnih veličina potrebnih za izvođenje vjerodostojnih simulacija.

5.1. MATLAB PROGRAMSKO OKRUŽENJE

MATLAB je korišten za izradu cjelokupne logike iza sustava adaptivnog upravljanja prometom, dinamičko upravljanje parametrima simulacije i zabilježbu rezultata unutar ovog rada, dok je PTV VISSIM korišten za izradu modela, što uključuje određivanje prometne potražnje na pojedinim privozima, postavljanje elemenata prometnica te korištenje fiksnog signalnog plana kako bi usporedba s adaptivnim koji slijedi bila moguća.

MATLAB (engl. MATrix LABoratory) je ujedno i programski jezik i interaktivna okolina za razvijanje algoritama, analizu i vizualizaciju podataka te za matematičke izračune [11]. Koristi se ponajviše u svrhu edukacije i istraživanja na sveučilištima tehničkih područja, ali nalazi i intenzivnu primjenu u industriji. Posebnost MATLABA se očituje u korištenju vektora odnosno matrica s kompleksnim brojevima kao osnovni tip podataka što omogućava lako rješavanje niza problema iz inženjerstva i znanosti. Zbog mogućnosti pisanja koda sličnog stvarnom izgledu matematičkih formula moguće je jednom linijom koda napisanom u MATLABU zamijeniti niz linija koda napisanih u jeziku zasnovanom na skalarnim izračunima kao što su C++ ili Fortran. Također je vrlo lak i intuitivan način vizualiziranja podataka kroz razne vrste 2D i 3D grafova. Osim osnovnog paketa moguće je nadograditi programsku okolinu s nizom programskih alata (engl. toolboxes) koji pokrivaju gotovo sva područja inženjerske djelatnosti. Neke od nadogradnji su:

- Fuzzy Logic Toolbox – nadogradnja za razvijanje sustava neizrazite logike
- Statistics and Machine Learning Toolbox – nadogradnja za opisivanje, analiziranje i modeliranje podataka

- Neural Network Toolbox – nadogradnja koja pruža algoritme, modele i aplikacije za stvaranje neuronskih mreža
- Simulink Control Design – nadogradnja za dizajniranje i analiziranje sustava upravljanja
- Signal Processing Toolbox – nadogradnja koja pruža funkcije i aplikacije za analiziranje, predprocesiranje i ekstrakciju svojstava uzorkovanih signala
- Image Processing Toolbox – nadogradnja pruža set algoritama i aplikacija za analizu slike te razvijanje algoritama računalnog vida

Osim mnoštva raznih nadogradnji, oko MATLAB-a je s vremenom okupio i aktivnu zajednicu ljudi koji doprinose širenju znanja kroz dijeljenje svojih kodova sa ostalima. Upravo je iz tog razloga MATLAB vrlo popularan jer dodatne module mogu proizvoditi i sami korisnici [10].


5.2. NEIZRAZITA LOGIKA U MATLAB OKRUŽENJU

U svrhu dizajniranja sustava adaptivnog upravljanja korišten je MATLAB-ov „Fuzzy Logic Toolbox“ koji preglednošću raznovrsnog grafičkog sučelja omogućuje praćenje svih aspekata neizrazitog sustava. Grafičko sučelje koje je potrebno za izradu cjelokupnog sustava odnosi se na prikaze ulaza i izlaza sustava te njihovih međusobnih vrijednosti, grafičkih prikaza međuodnosa pojedinih ulaza te načina na koji se odražavaju na izlaz.

Glavna sučelja Fuzzy Logic Designera korištena su:


- Prikaz ulaznih i izlaznih varijabli (Slika 11);
- Prikaz funkcija pripadnosti (Slike 12 i 13);
- Sučelje za kreiranje i promjenu pravila neizrazite logike (Slika 14);
- Grafički prikaz skupa svih pravila te njihov međusobni utjecaj na izlazne varijable (Slika 15);
- Trodimenzionalnih grafova za ovisnost parova ulaznih varijabli s izlazima (Slika 16);
- Grafičko sučelje za prikaz dvodimenzionalnih grafova pojedinih varijabli (Slika 17).

Kako bi stvarnovremenska obrada prometnih podataka bila moguća, MATLAB prikuplja informacije o stanju detektora na kolniku unutar simulacijskog vremena. Prikupljeni prometni podaci omogućavaju MATLAB-u izvođenje dinamičke promjene faza tijekom simulacije na temelju neizrazitog sustava koji je u simulaciju uključen.




Slika 11. Sučelje za prikazivanje varijabli ulaza i izlaza

MATLAB pruža mogućost prilagodbe funkcija pripadnosti za svaki pojedini ulaz, a najbolji primjer može se promatrati na grafovima za glavne (Slika 12) i sporedne privoze (Slika 13). Unutar sučelja za prikaz funkcija pripadnosti moguće je vidjeti kako će funkcija za glavne privoze puno brže doći do svoje visoke vrijednosti od one za sporedne privoze. Funkcije pripadnosti unutar Fuzzy Logic Designer-a na slici 12 pokazuju vrijednosti koje izlazna varijabla „Hitnost“ treba poprimiti da bi spadala u jednu od kategorija: „niska“, „srednja“ ili „visoka“. Funkcija s oznakom „niska“ zahvaća najmanju udaljenost na grafu čime se omogućuje brža kategorizacija hitnosti kao „srednja“ ili „visoka“, upravo zbog već spomenute prednosti dane glavnim privozima.



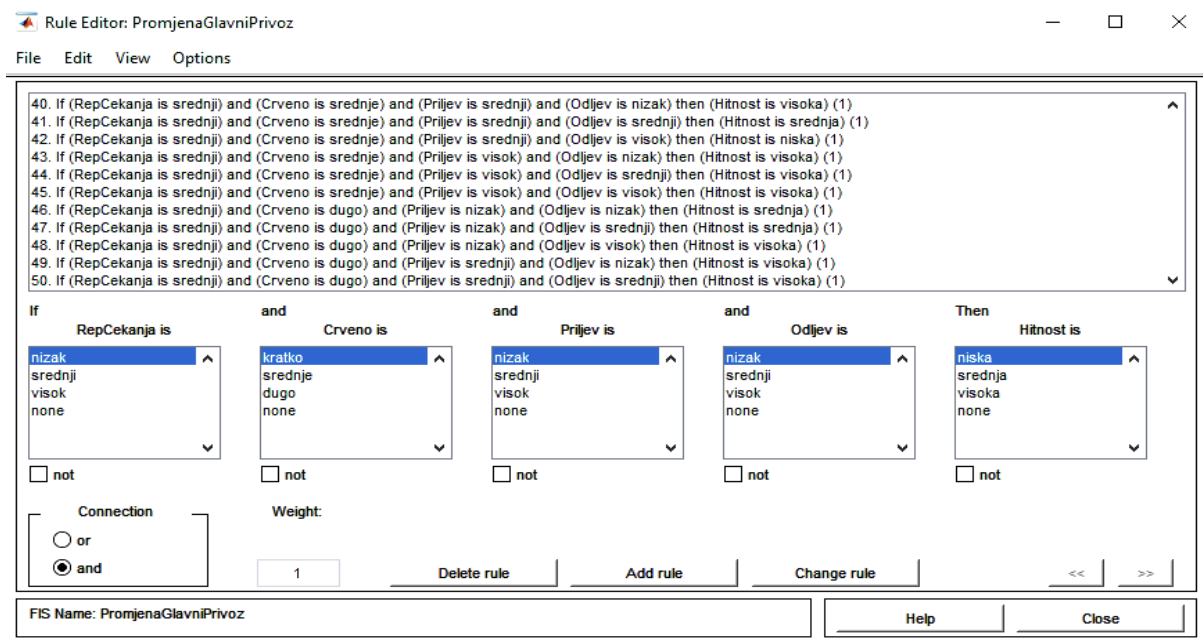
Slika 12. Sučelje za namještanje funkcija pripadnosti glavnih privoza

Na slici 13 može se vidjeti razlika u odnosu na glavni privoz, s obzirom na to da hitnost puno teže „napušta“ funkciju pripadnosti označenu s „niska“. Funkcija za vrijednosti hitnosti označena s „visoka“ također je pomaknuta udesno kako bi sporedni privozi teže dostigli svoju najvišu vrijednost hitnosti. Time je osigurana prednost glavnih nad sporednim privozima u kontekstu hitnosti neizrazite logike.



Slika 13. Sučelje za namještanje funkcija pripadnosti sporednih privoza


Funkcije pripadnosti unutar Fuzzy Logic Designer-a pokazuju stupnjeve vrijednosti (niska srednja visoka) koje svaka pojedina varijabla može poprimiti te ih potom kombinira zajedno s pravilima kojih u ovom slučaju ima 81. Na taj način pokrivene su sve moguće kombinacije vrijednosti ulaznih varijabli reda čekanja, trajanja crvenog svjetla, priljeva i odljeva vozila te izlazne varijable – hitnosti. Sučelje za dizajniranje pravila (Slika 14) omogućuje vrlo fleksibilan rad, s obzirom na to da pruža mogućnost odabira, promjene te pisanje novih pravila u bilo kojem trenutku.



Slika 14. Sučelje za dizajniranje pravila neizrazitog sustava upravljanja unutar MATLAB-a

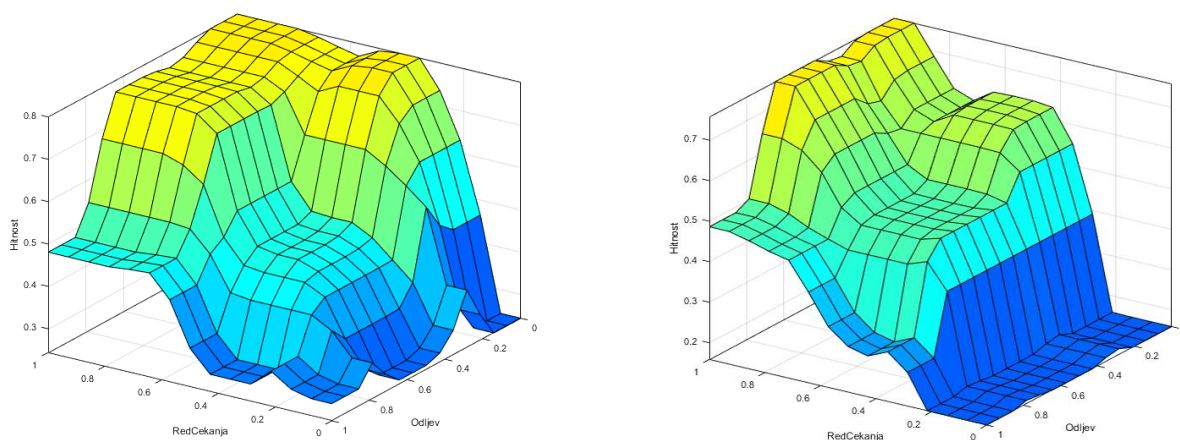
Varijable ulaza te vrijednosti koje svaka poprима unutar svojih funkcija pripadnosti defuzifikacijom se pretvaraju u decimalne vrijednosti te se s obzirom na njihovu kombinaciju

među sva 4 ulaza dobiva vrijednost na izlazu. Na slici 15 prikazano je kako se kombinacija vrijednosti svih ulaza odražava a stanje hitnosti.



Slika 15. Međusobni utjecaj varijabli neizrazite logike


Međuodnosi pojedinih veličina ulaza usporedno s izlazima moguće je promatrati na trodimenzionalnim „Surface“ grafovima koji su također dio Fuzzy Logic Designer-a. Jedina poteškoća pri očitavanju takvih grafova jest mogućnost istovremenog pregleda samo dva ulaza naprema izlazu, što zahtijeva učestalo provjeravanje ostalih kombinacija ulaza kao i njihove promjene koje se mogu dogoditi u slučaju promjene nekog od pravila na trenutno promatranom grafu.



Slika 16. Odnos reda čekanja i odljevnih vrijednosti neizrazite logike glavnih (lijevo) i sporednih privoza (desno)

Na slici 16 jasno je iz grafova s prikazom ploha odnosa ulaznih varijabli vidljiva gradacija koju pravila za odljev i red čekanja čine naprema sveukupnoj hitnosti. Posebno je potrebno obratiti pažnju na razliku u strmosti dvaju prikazanih grafova te kako se ona odražava na to koliko će se naglo promjena dogoditi u oba slučaja. U ovom reprezentativnom prikazu naglasak je na puno veće potrebno prometno opterećenje u slučaju sporednih privoza kako bi se postigla ista hitnost kao u glavnim privozima.

Graf na slici 17, reprezentativni je slučaj funkcije varijable ulaza, u ovom slučaju odljeva vozila. Osim praćenja međudnosa varijabli promatrajući grafove s prikazom plohe odnosa ulaznih varijabli, također je važno voditi računa o obliku samostalnih funkcija pojedinih ulaza naprema izlazu, budući da su pripadne funkcije varijabli najbolji opis njihovog ponašanja koji se prenosi na odnos s drugim varijablama [12].



Slika 17. Sučelje za prikaz pojedinačnih funkcija ovisnosti varijabli ulaza naprema izlazu

Potrebno je također spomenuti uporabu težina (engl. weights) neizrazite logike unutar MATLAB-a na slici 14, koje pojačavaju ili smanjuju stupanj uporabe pojedinog pravila unutar sučelja za upravljanje neizrazitom logikom. Uporaba težina neizrazite logike je kontekstualna te zahtjeva određeno testiranje sustava prije nego se može znati koja pravila bi trebala imati veći, a koja manju težinu. S obzirom na to da vrijednosti koje težine poprimaju sežu od „0“ do „1“, a automatski postavljena vrijednost težina svih pravila unutar MATLAB iznosi „1“, ako se neko od pravila treba pojačati u svom djelovanju, potrebno je smanjiti jačinu svih pravila osim tih nekoliko čije se djelovanje želi pojačati.

5.3. SIMULACIJSKI PAKET PTV VISSIM

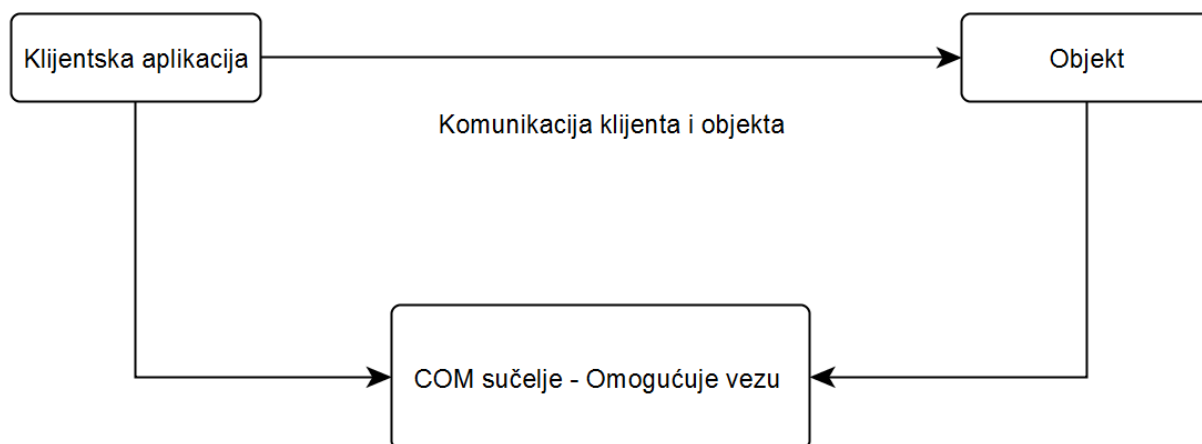
Za izvođenje prometnih simulacija u ovom radu je korišten PTV VISSIM 10. PTV VISSIM (njem. Planung Transport Verkehr Verkehr In Städten – SIMulationsmodell) je mikrosimulacijski alat koji služi za modeliranje gradske cestovne prometne mreže i operacija javnog gradskog prijevoza te tokova pješaka. Pojam „mikrosimulacija“ označava da su tijekom

simulacije svaki prometni entitet simuliran kao zasebna jedinka te da vrši interakciju s drugim prometnim entitetima, umjesto da su predstavljeni na neki pojednostavljen i općeniti način. Za određivanje putanje vozila koristi se takozvano ponašanje vozača (engl. driver behaviour) te fizičke karakteristike vozila, dok se vozila unutar modela prometnice pojavljuju korištenjem statističke distribucije te se njihovo kretanje nadzire svake simulacijske sekunde [9]. Wiedemann je 1974. godine razvio psiho-fizički model percepcije izrađen prema ljudskoj percepciji i brzini reakcije koji Vissim koristi u svrhu što boljeg prikaza ponašanja vozača, odnosno vozila prilikom simulacije. Osnova Wiedemannovog modela jest da vozilo koje se kreće većom brzinom, počne usporavati korištenjem vlastite percepcije ukoliko se počne približavati vozilu koje se kreće manjom brzinom. [13]

5.4. POVEZIVANJE APLIKACIJA COM SUČELJEM

Veza između VISSIM-a i MATLAB-a moguća je uz pomoć COM (engl. Component Object Model) sučelja. COM sučelje predstavlja standardizirani mehanizam za izmjenu podataka između različitih programa. Veza između programa zasniva se na odnosu klijentske i poslužiteljske aplikacije. U ovom radu ostvaruje se veza ova dva programa u kojoj MATLAB poprima ulogu klijentske aplikacije, dok je VISSIM aplikacija poslužitelj. COM sučelje služi striktno za uspostavu komunikacije između dva programa, uspostavljajući vezu između njihovih protokola, što znači da nakon uspostavljanja veze COM sučelje više ne predstavlja nikakav faktor u komunikaciji između aplikacija, nego se razmjena podataka vrši između dvaju programa. Općeniti način rada COM sučelja prikazan na slici 18. te se unutar VISSIM-a može koristiti u svrhu [8]:

- Pripremanja i naknadna obrada simulacijskih podataka;
- Učinkovitog upravljanja različitim signalnim planovima i prometnim podacima za pregledavanje scenarija;
- Uključivanja definiranih algoritama upravljanja;
- Pristupanja svim atributima mrežnih objekata.



Slika 18. Način rada COM sučelja

Za pristupanje objektima je uvijek potrebno pratiti hijerarhiju klasa. Objekt IVissim je najviše rangirani objekt preko kojeg pristupamo objektima INet (engl. network - mreža) i ISimulation (engl. simulation - simulacija) te kroz njih pristupamo nižim objektima kao što su ILink (engl. link – poveznice, ceste), IDetector (engl. detector - detektor), IQueueCounter (engl. queuecounter – mjerac reda čekanja) itd.

U ovom radu se iz VISSIM-a preuzimaju podaci u za vrijeme i poslije simulacije. Za vrijeme simulacije se kontinuirano preuzimaju podaci o stanju detektora koji se obrađuju za dobivanje redova čekanja i prometnih tokova. Na kraju simulacije se preuzimaju određeni evaluacijski parametri koje VISSIM generira. Osim preuzimanja podataka iz MATLAB-a se šalju podaci o stanju semafora na raskrižju, ili kada dolazi do kraja faze ili kada se unutar faze mijenjaju svjetlosni pojmovi.

6. REZULTATI SIMULACIJA


Za provjeru kvalitete rada implementiranog upravljačkog zakona, korištena je simulacija stvarnog semaforiziranog raskrižja Zagrebačke ulice i Zagrebačke avenije te su korišteni stvarni signalni planovi pripadni tom raskrižju. U ovom poglavlju prikazani su rezultati korištenog sustava adaptivnog upravljanja zasnovanog na neizrazitoj logici te je dan osvrt na promjene koje je adaptivni sustav donio u odnosu na fiksno upravljanje. U svrhu pravilnog postavljanja reference za dobivene rezultate, svaka će adaptivna simulacija s obzirom na potražnju biti uspoređena s njoj pripadnom fiksnom simulacijom. Simulirana su tri slučaja prometne potražnje: takozvana „srednja potražnja“ koja odgovara realnoj potražnji na simuliranom modelu raskrižja Zagrebačke avenije i Zagrebačke ulice, „+40“ potražnja koja simulira 40% veću potražnju te slučaj „-40%“ pri kojem je potražnja na istom raskrižju umanjena za 40%. Svaki od navedenih slučajeva potražnje simulira se dva puta, jednom za slučaj fiksnog i jednom za slučaj adaptivnog upravljanja. Budući da svaka kombinacija načina upravljanja i prometne potražnje zahtjeva 10 simulacija s različitim sjemenom kako bi rezultati bili vjerodostojni da se uzmu u obzir, kako bi se zahvatili svi potrebni slučajevi, prikazani su rezultati ukupno 60 simulacija. Tijekom simulacija najugroženiji se pokazao zapadni privoz, specifično lijevi skretači, što nije neobično s obzirom na veličinu prometne potražnje. Kako bi simuliranje bilo jasnije prikazano, tablica 4 daje uvid u cjelokupnu listu prometne potražnje koja je korištena u svrhu simuliranja na raskrižju Zagrebačke avenije i Zagrebačke ulice.

Tablica 4. Prometna opterećenja po privozima i scenarijima [voz/h]


Scenariji simulacije	Zagrebačka avenija – Zagrebačka ulica		Zagrebačka ulica – Petrovaradinska ulica	
	zapad - istok	istok - zapad	jug - sjever	sjever - jug
Normalna potražnja	2.717	3.370	407	943
+40% potražnja	3.803,8	4.718	569,8	132,2
-40% potražnja	1.630,2	2.022	244,2	565,8

Naposljetku preostaje još analizirati dobivene rezultate simulacija. Na sljedećim je grafičkim prikazima moguće pratiti izmjenu faza tijekom nekoliko reprezentativnih primjera simulacija, kao i popunjenost nekih od pojedinih prometnih traka koje se ističu kao značajni primjeri u ovom završnom radu.

Na slici 19 prikazan je način na koji se faze tijekom svakog sljedećeg ciklusa ponavljaju. Naravno riječ je o fiksnom upravljanju te je potrebno napomenuti da je struktura NEMA uključena u izračun tek korištenjem adaptivnog upravljanja te s obzirom na to, ovakav prikaz reprezentativan je za svih 30 simulacija fiksnog upravljanja bez obzira o kojem se scenariju potražnje radi.



Slika 19. Prikaz promjene faza tijekom fiksnog upravljanja




Slika 20. Prikaz izmjene faza korištenjem strukture NEMA i implementiranog neizrazitog sustava upravljanja


Rad strukture NEMA moguće je vidjeti na slici 20, gdje je moguće promatrati način na koji se unutar ukupno 24 faza jedne simulacije dinamički kroz vrijeme izmjenjuju sve definirane faze. Osim obaveznih faza prikazanih slikom 19, ovdje se po potrebi uključuju i opcionalne faze naznačene brojevima 5, 7 i 8 u ovom slučaju.

6.1. REZULTATI SCENARIJA SREDNJE PROMETNE POTRAŽNJE

Prvi scenarij simulacije odnosi se na srednju prometnu potražnju. Ovaj je slučaj poprilično bitan budući da predstavlja moguće ponašanje adaptivnog sustava upravljanja u slučaju korištenja unutar već postojeće infrastrukture simuliranog raskrižja. Slike 21 i 22 prikazuju popunjenost traka 1 i 2, korištenjem brojača redova čekanja prilikom izmjene faza uporabom strukture NEMA.




Slika 21. Izmjena faza pri scenariju srednje prometne potražnje



Slika 22. Popunjenost trake 1 po fazama pri srednjoj prometnoj potražnji

Već u simuliranju srednje prometne potražnje pojavljuje se zagušenje u 8. fazi, kako je prikazano na slici 22, dok već na početku 4. faze popunjenost prve trake iznosi skoro 60%. Faza koja je simulirana 8. po redu jest obavezna faza pod brojem 2 u definiranom signalnom planu koji se izvodi prema strukturi NEMA te zahvaća zapadne i istočne privoze, odnosno trake s najvećom prometnom potražnjom. Stoga i ne čudi što su rezultati pogoršani u odnosu na fiksni plan baš u tom trenutku simulacije.



Slika 23. Popunjenost trake 2 po fazama pri srednjoj prometnoj potražnji

Duljina redova čekanja na slici 23 također jasno ukazuje na veliki skok u popunjenosti toka koji se mjeri na drugoj traci, također u 8. simuliranoj fazi. Podaci svake simulacije pokazuju kako se jedino na prvoj prometnoj traci događa zagušenje koje se ne uspijeva razriješiti, dok se sve ostale prometne trake uspiju osloboditi vozila odmah po završetku spomenute faze.


Na sljedećim grafičkim prikazima rezultata, oznake i njihova objašnjenja prikazuju:

QL – prosječnu duljinu reda čekanja,

QLM – duljinu najduljeg reda čekanja,


QS – broj stajanja na semaforiziranom raskrižju,

dok indeksi „Z“, „J“, „I“ i „S“ označavaju stranu svijeta na kojoj se privoz nalazi.



Slika 24. Rezultati usporedbe srednje potražnje adaptivnog i fiksog upravljanja

Rezultati usporedbe fiksog i adaptivnog prometnog upravljanja na slici 24. jasno pokazuju da adaptivni sustav za promjenu faza daje poboljšanje na svim privozima osim na zapadnom. Razlog tome su upravo lijevi skretači koji se nalaze na zapadnom privozu simuliranog semaforiziranog raskrižja. Nasuprot tome, svi sastali privozi pokazuju jasne znakove poboljšanja, uključujući i istočne tokove koji spadaju u glavnu vrstu privoza te se od južnih i sjevernih po prometnoj potražnji znatno razlikuju.




Slika 25. Rezultati usporedbe srednje potražnje adaptivnog i fiksnog upravljanja korištenjem alternativne strukture NEMA


Uspoređujući slučajeve gdje se koriste dvije različite kompozicije strukture NEMA, odmah je uočljivo kako se postiglo djelomično poboljšanje u slučaju srednje prometne potražnje na zapadnom privozu koji je predstavljao problem u prvom slučaju, kako se može vidjeti na slici 25. Nažalost, poboljšanje zapadnih privoza povlači za sobom pogoršanje na sjevernom i južnom privozu zbog rasporeda vremena ciklusa između naknadno dodane faze i već korištenih faza. Usprkos tome, istočni privoz pokazuje u ovom slučaju znatno poboljšanje, čak i preko 40%.

6.2. REZULTATI SCENARIJA UMANJENE PROMETNE POTRAŽNJE


Drugi scenarij podrazumijeva simuliranje uz -40% prometne potražnje te su rezultati same promjene faza prikazani na slici 26, dok je zauzeće mreže tijekom simulacije moguće pratiti na slikama 27 i 28. Promjena faza za umanjenu prometnu potražnju pokazuje kako je samo u početku simulacije bilo potrebe za aktiviranjem opcionalne 5. faze koju sadrži struktura NEMA.




Slika 26. Izmjena faza pri scenariju umanjene prometne potražnje



Slika 27. Popunjenost prve prometne trake pri umanjenoj potražnji




Slika 28. Rezultati usporedbe srednje potražnje adaptivnog i fiksnog upravljanja



Slika 29. Rezultati usporedbe niske potražnje adaptivnog i fiksnog upravljanja

Scenarij umanjene potražnje bilježi jako zadovoljavajuće rezultate koje je moguće vidjeti na slici 29. Ovdje je zabilježeno najveće poboljšanje rada sustava u usporedbi s fiksnim upravljanjem na gotovo svim privozima. Na temelju ovog prikaza može se zaključiti da sustav izmjene faza najbolje radi pri nižoj prometnoj potražnji te da je jedino u tom slučaju minimizirana potreba za optimizacijom jednih privoza na štetu drugih.




Slika 30. Rezultati usporedbe niske potražnje adaptivnog i fiksnog upravljanja korištenjem alternativne strukture NEMA

Slučaj umanjene potražnje u kombinaciji s drugom strukturom NEMA također pokazuje pogoršanje u odnosu na prvu, najznačajnije na južnom privozu, gdje pogoršanje iznosi oko 40%, vidljivo na slici 30. Ovi rezultati i njihova usporedba pokazuju kako korišteni sustav izmjene faza daje skoro apsolutno poboljšanje korištenjem prve strukture NEMA te kako ponavljanjem jedne od faza u drugom signalnom planu vrijeme koje je dodano u ciklusu znatno pogoršava rad sustava.


6.3. REZULTATI SCENARIJA UVEĆANE PROMETNE POTRAŽNJE

Treći scenarij prikazuje rezultate adaptivnog upravljanja pri uvećanoj prometnoj potražnji za +40%. Pri simuliranju svakog od dosad definiranih scenarija prometne potražnje može se primijetiti pogoršanje u na zapadnom privozu, no prilikom simuliranja slučaja povećane prometne potražnje, taj je problem najviše došao izražaja. Prilikom testiranja rješenja koja bi potencijalno poboljšala rezultate simulacija, otkriveno je da je razlog ovome fiksno vrijeme ciklusa te time i faza, kao i neponavljanje 1. faze kroz cijeli ciklus, odnosno one unutar koje se nalazi prometna traka lijevih skretača. Slika 31 pokazuje pojavljivanje 5. faze, odnosno one u čijoj se kompoziciji nalazi tok lijevih skretača, samo u prvom dijelu simulacije, što naravno uzrokuje daljnje probleme s prometnim zagušenjem.




Slika 31. Prikaz popunjenosti prve prometne trake tijekom izmjene faza prilikom adaptivnog upravljanja uvećane prometne potražnje

Slika 32 najbolje ukazuje na problematiku lijevih skretača pri simuliranju uvećane prometne potražnje. Moguće je primijetiti kako se već u 3. fazi red čekanja 1. prometne trake uveća za približno 40%, dok u 8. fazi nastaje potpuno zagušenje koje se uspijeva razriješiti do kraja simulacije kao i u prijašnjim scenarijima. Taj se slučaj nastavio ponavljati kroz sve simulacije uvećane potražnje.




Slika 32. Prikaz popunjenosti druge trake tijekom izmjene faza prilikom primjene adaptivnog upravljanja i uvećane prometne potražnje

Uspoređujući popunjenost prometne trake 1 pri uvećanoj potražnji, vrlo je jasno vidljivo na slici 33 kako je i 2. prometna traka stalno na rubu prometnog zagušenja. Također je moguće uočiti kako se popunjenost trake naglo periodički povećava, u 7. fazi za skoro 80%.




Slika 33. Izmjena faza pri uvećanoj prometnoj potražnji



Slika 34. Rezultati usporedbe uvećane potražnje adaptivnog i fiksnog upravljanja

Naposljetku, problemi koji se javljaju primjenom adaptivnog upravljanja korištenjem izmjene faza najviše se očituju u rezultatima uvećane prometne potražnje. Na rezultatima koje prikazuje slika 34 moguće je promatrati reakciju vozila zapadnog privoza na adaptivni sustav izmjene faza. Među prometne trake zapadnog privoza uključeni su i već spomenuti lijevi skretači koji, kako je moguće vidjeti, stvaraju najveći red čekanja te naposljetku i potpuno zagušenje cjelokupnog zapadnog privoza.



Slika 35. Rezultati usporedbe uvećane potražnje adaptivnog i fiksnog upravljanja

Veliko pogoršanje uzrokovano prvom korištenom strukturom NEMA u ovom je slučaju popravljeno za više od 50%, kako je prikazano na slici 35, no problemi se javljaju na drugim privozima gdje sada postoji manje poboljšanje nego u prijašnjem slučaju gdje je korištena prvotna verzija strukture NEMA. Ovdje je najviše do izražaja došla nemogućnost sustava da samo izmjenom faza optimizira uvećanu potražnju s obzirom na fiksno trajanje faza. Ponavljanjem prve faze u cilju poboljšanja rezultata nastojalo se primarno omogućiti oslobađanje toka lijevih skretača koji najviše doprinose zagušenju nastalom unutar simuliranog semaforiziranog raskrižja.

7. ZAKLJUČAK

Adaptivni način upravljanja semaforiziranim raskrižjem u konačnici se pokazuje kao daleko učinkovitije rješenje od dosadašnje vrlo često korištenih fiksnih sustava. Neizrazita logika nalazi svoju primjenu u moderniziranju upravljanja prometnom infrastrukturom te svojom fleksibilnošću i zahtijevanjem poznavanja samog sustava daje čvrstu osnovu za izradu sustava adaptivnog upravljanja. Usprkos tome, samo poznavanje načina rada sustava nije dovoljno s obzirom na to da se pravila neizrazite logike dizajniraju po vlastitoj procjeni prometnog stručnjaka. Promjena redoslijeda faza u sklopu adaptivnog upravljanja semaforiziranim raskrižjem pokazala se kao vrlo dobro rješenje u slučaju srednje i umanjene prometne potražnje, dok je za uvećanu prometnu potražnju potrebna daljnja optimizacija postojećeg sustava adaptivnog upravljanja. Promatrano semaforizirano raskrižje uz izmjenu svakako zahtjeva i optimizaciju vremena trajanja faza prilikom rada sustava, s obzirom na to da je samo eksperimentiranje s trajanjem faza, a time i trajanja ciklusa znatno utjecalo na dobivene rezultate.

Mogućnost nadogradnje postojećeg sustava adaptivnog upravljanja je dodavanje evolucijskog algoritma kao što je to npr. genetski algoritam. Takvi algoritmi omogućuju da se pravila neizrazite logike kroz određeni broj simulacija optimiziraju tijekom rada upravljačkog sustava prema odabranoj kriterijskoj funkciji i s obzirom na prometnu potražnju simuliranog semaforiziranog raskrižja.

LITERATURA

[1] Vujić, M.: „Cestovna telematika - Signalni plan“, predavanja, Fakultet prometnih znanosti, Zagreb, 2017.

[2] Lam, J.: „Challenges and benefits of adaptive signal control“

Preuzeto sa: <http://www.itsinternational.com/sections/nafta/features/challenges-and-benefits-of-adaptive-signal-control/> [Pristupljeno: kolovoz 2018.]

[3] Vujić, M.: „Cestovna telematika - Osnovni pojmovi iz područja cestovne telematike“, predavanja, Fakultet prometnih znanosti, Zagreb, 2016.

[4] Vujić, M.: „Cestovna telematika - Strategije i taktike upravljanja prometom“, predavanja, Fakultet prometnih znanosti, Zagreb, 2016.

[5] Gold, H.: „Umjetna inteligencija - Neizrazita logika – Skupovi“, predavanja, Fakultet prometnih znanosti, Zagreb, 2010.

[6] Duo Li1, Prakash Ranjitkar: „A fuzzy logic-based variable speed limit controller“, 2015.

[7] Jee-Hyong Lee, Hyung Lee-Kwang: „Distributed and Cooperative Fuzzy Controllers for Traffic Intersections Group“, IEEE Transactions On Systems, Man And Cybernetics—Part C: Applications And Reviews, VOL. 29, NO. 2, MAY 1999.

[8] Skružný, F.: „Control System Development of Traffic Signal Control in MATLAB for PTV VISSIM“, Czech Technical University of Prague Faculty of Transportation Sciences Department of Transport Telematics, Master's thesis, 2017.

[9] Vujić, M.: „Cestovna telematika – Uvod u simulacijske alate“, predavanja, Fakultet prometnih znanosti, Zagreb, 2016.

[10] Ban Ž., Matuško J., Petrović I.: „Primjena programskog sustava MATLAB za rješavanje tehničkih problema“, Graphis, 2010.

[11] Cohan, K.: „MATLAB Overview“, MathWorks

Preuzeto sa: <https://www.mathworks.com/videos/matlab-overview-61923.html> [Pristupljeno: kolovoz 2018.]

[12] Naveed, A.: „Fuzzy Logic Control Using Matlab Part II“, FAST-NUCES, Lahore, 2003.
Preuzeto sa: <https://khwarizmi.org/system/files/activities/115/flc2.pdf> [Pristupljeno: kolovoz 2018.]

[13] Abbas, M.M., Higgs, B., Medina, A., „Analysis of the Wiedemann Car Following Model over Different Speeds using Naturalistic Data“, Virginia Tech, 2011.

POPIS SLIKA

Slika 1. Općeniti primjer korištenja faza u fiksnom signalnom planu [2]	2
Slika 2. Fiksni signalni plan korištenog semaforiziranog raskrižja Zagrebačke ulice i Zagrebačke avenije	4
Slika 3. Prikaz osnovne građe prstenaste strukture NEMA	6
Slika 4. Prikaz korištene prstenaste strukture NEMA	7
Slika 5. Prikaz funkcije pripadnosti izrazitom skupu, [5]	10
Slika 6. Prikaz funkcije pripadnosti neizrazitom skupu, [5]	11
Slika 7. Proces odlučivanja primjenom neizrazite logike	11
Slika 8. Prikaz cjelokupnog djelovanja neizrazitog sustava za izmjenu faza	14
Slika 9. Prikaz označavanja detektora unutar modela semaforiziranog raskrižja	14
Slika 10. Prikaz određivanja hitnosti faza	16
Slika 11. Sučelje za prikazivanje varijabli ulaza i izlaza	19
Slika 12. Sučelje za namještanje funkcija pripadnosti glavnih privoza	20
Slika 13. Sučelje za namještanje funkcija pripadnosti sporednih privoza	21
Slika 14. Sučelje za dizajniranje pravila neizrazitog sustava upravljanja unutar MATLAB-a	21
Slika 15. Međusobni utjecaj varijabli neizrazite logike	22
Slika 16. Odnos reda čeka i odljevnih vrijednosti neizrazite logike glavnih (lijevo) i sporednih privoza (desno)	22
Slika 17. Sučelje za prikaz pojedinačnih funkcija ovisnosti varijabli ulaza naprema izlazu ...	23
Slika 18. Način rada COM sučelja	25
Slika 19. Prikaz promjene faza tijekom fiksnog upravljanja	27
Slika 20. Prikaz izmjene faza korištenjem strukture NEMA i implementiranog neizrazitog sustava upravljanja	28
Slika 21. Izmjena faza pri scenariju srednje prometne potražnje	29
Slika 22. Popunjenost trake 1 po fazama pri srednjoj prometnoj potražnji	30
Slika 23. Popunjenost trake 2 po fazama pri srednjoj prometnoj potražnji	31
Slika 24. Rezultati usporedbe srednje potražnje adaptivnog i fiksnog upravljanja	32
Slika 25. Rezultati usporedbe srednje potražnje adaptivnog i fiksnog upravljanja korištenjem alternativne strukture NEMA	33
Slika 26. Izmjena faza pri scenariju umanjene prometne potražnje	34
Slika 27. Popunjenost prve prometne trake pri umanjenoj potražnji	35
Slika 28. Rezultati usporedbe srednje potražnje adaptivnog i fiksnog upravljanja	35
Slika 29. Rezultati usporedbe niske potražnje adaptivnog i fiksnog upravljanja	36

Slika 30. Rezultati usporedbe niske potražnje adaptivnog i fiksnog upravljanja korištenjem alternativne strukture NEMA	37
Slika 31. Prikaz popunjenosti prve prometne trake tijekom izmjene faza prilikom adaptivnog upravljanja uvećane prometne potražnje	38
Slika 32. Prikaz popunjenosti druge trake tijekom izmjene faza prilikom primjene adaptivnog upravljanja i uvećane prometne potražnje	39
Slika 33. Izmjena faza pri uvećanoj prometnoj potražnji	40
Slika 34. Rezultati usporedbe uvećane potražnje adaptivnog i fiksnog upravljanja	41
Slika 35. Rezultati usporedbe uvećane potražnje adaptivnog i fiksnog upravljanja	42

POPIS TABLICA

Tablica 1. Duljina ciklusa s obzirom na broj faza

Tablica 2. Vrijednosti funkcija izrazitih skupova

Tablica 3. Vrijednosti funkcija neizrazitih skupova

Tablica 4. prikazuje prometna opterećenja po privozima i scenarijima [voz/h]

ZAHVALE

Zahvaljujem svom mentoru izv. prof. dr. sc. Edouardu Ivanjku na brojnim savjetima, velikoj podršci i pomoći prilikom izrade ovog završnog rada. Također zahvaljujem svojim kolegama Izidoru Oremoviću i Alanu Vogelu na suradnji te značajnom doprinosu projektu na kojem se zasniva ovaj završni rad. Želim također zahvaliti svojoj obitelji i prijateljima koji su me podupirali tijekom izrade ovoga rada.




Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj _____ završni rad
isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na
objavljenu literaturu što pokazuju korištene bilješke i bibliografija.
Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz
necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.
Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj
visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.
Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu _____ završnog rada
pod naslovom **Mogućnosti primjene neizrazite logike za određivanje redoslijeda**
faza kod semaforiziranih raskrižja
na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom
repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 10.9.2018 _____



(potpis)